

類神經網路預測台灣 50 股價指數之研究

The Study of Neural Network to Predict Taiwan ETF-50 Stock Index Price

黃華山 邱一薰

國立彰化師範大學資訊管理研究所

Hwa-Shan Huang, I-Hsun Chiu

Department of Information Management, National Changhua University of Education

huanghs@cc.ncue.edu.tw

robert_chiu@msn.com

摘要

本論文是運用倒傳遞類神經網路做為預測台灣 50 股票指數的研究。台灣 50 (ETF50)「指數股票型證券投資信託基金」，其指數之組成由台灣排名前 50 大之股票指數，依公司市值比例組成。因此，本研究利用其組成關係，找出台灣 50 排名前 20 名之成份股以及台灣 50 指數以往之技術指標資料，按成分股權重比例之影響，做為輸入類神經網路訓練之變數資料。本研究將收集到的樣本切割成兩部份，356 筆日資料為訓練資料；100 筆日資料為測試期資料。類神經網路經過訓練後、模擬 ETF50 股價指數，再選出 5 個平均誤差最小者，搭配本研究提出之交易策略，計算可獲取之投資報酬。經實驗發現：一、本研究提出之類神經網路模式具有良好的預測能力；二、類神經網路模式配合本研究提出之交易策略可獲得較高的報酬。

關鍵詞：倒傳遞類神經網路，台灣 50

Abstract

This study is based on Back-propagation neural network theory to forecast Taiwan Top50 Exchange Tracker Fund (ETF50). Because ETF50 is composed of Taiwan Top 50 representative firms, this study applies the technical index of ETF50 and the top 20 of ETF50 stock indices as the inputs of the neural network. Our sample data is mainly separated into two parts, 356 records of training data and 100 records of testing data. After training the neural network, simulating the ETF50 price index and comparing with the mean square error, I choose the top 5 prediction modes. Besides, a speculative trading strategy is applied to evaluate the performance of the best return prediction model. Through my experiment, I found two points: 1. the neural network model proposed has good prediction capability; 2. neural network model applied with my speculative trading strategy can obtain higher return.

Keywords: Back-propagation neural network, ETF 50

壹、緒論

影響股市漲跌的資訊非常多，諸如企業基本面、產業生態、總體經濟、投資心理、政治、國內外股市、國際情勢…等均是，而這些資訊很多是不明確的。投資大眾對股市的相關知識普遍欠缺，並在沒有事先做好相關功課和心理建設的情況下即進入股市進行投資，而上述這些不確定的資訊反應在投資大眾的心理層面上時，經常形成不必要的恐慌而迫使股市巨幅震盪，在這些股市震盪之下，大部份的投資者也無法獲得投資報酬。

影響股市變化情形的變數很多，而且變數之間的連動關係複雜很難加以釐清，這使得股市變化在預測有其難度與複雜性。雖然很多研究學者建立許多的統計預測模式，但是必需在諸多的基本假設限制條件之下進行方可，然而這些基本假設通常和現實世界的條件並不一致，如此一來便降低其應用的實用性與範圍。

時至今下，電子科技的進步使得電腦的運算處理能力的大幅提升，結合電腦的人工智慧技術得以處理複雜、龐大資訊問題。類神經網路為人工智慧的一種，由於它具有良好的容錯能力，即使一些的雜訊也可以準確預判結果，它大量應用在股市、期貨、債券評等的分析預測及研究。而在諸多的研究中發現，它的確具有相當的可信度及容錯力來處理這些龐大及複雜的資訊，並且獲得不錯的預測能力。

ETF50 股價指數是統合台灣市值前 50 大之股價指數，考慮到各股的流通量、流動性及市值等部份，並依據各股所佔市值比重與各股價指數的乘積加總而成[2]。其買賣方式與一般股票無異，上下漲跌幅限制為 7%，買賣手續費為 1.425%，主要差異在於證交稅為 1%，少於一般股票的 3%，而且，沒有平盤以下不得放空之限制。由於 ETF50 的組成及交易方式，因此使得其股價之變化與其它個股之漲跌，比較不會受到公司企業單獨事件之影響而使股價指數產生大幅度的變化。因此，以技術指標透過類神經網路的方式來預測 ETF50 股價指數應該是再適合不過的了。

本研究利用 ETF50 股價指數的組成方式，在訓練類神經網路訓練預測模型時，除了採用 ETF50 本身之歷史資料外，並且加入了 ETF50 排名前 20 家的成份股之技術資料，企圖以此方式找出能夠獲取超額投資報酬之類神經預測模式，以供投資大眾之參考。

貳、文獻探討

一、股市理論

(一)效率市場假說

Fama[16]在 1970 年歸納時國學術界的實證研究結果，認為資本市場具有效率性質(efficiency)，於是提出「效率市場假說(efficient market hypothesis, EMH)」。這個假說係指資本市場的所有資訊已經反應於價格上，因此投資人所收集的資訊並不能使其獲得超額利潤。

1.效率市場的四個基本假設

- (1)所有市場之參與者均可無償取得資訊。
- (2)所有投資者對各證券未來報酬率之機率分配有相同看法，同時投資者的現有

情報對股價的影響有相同之見解。

(3)證券交易無交易成本。

(4)市場完全競爭，所有投資人均為價格接受者。

2.效率市場假說之類型

Fama 將資本市場依資訊內容之不同而區分為三種不同的類型的假說，分別為「弱勢」、「半強勢」及「強勢」三種類型的假說。

(1)弱勢效率市場(weak form efficient market)

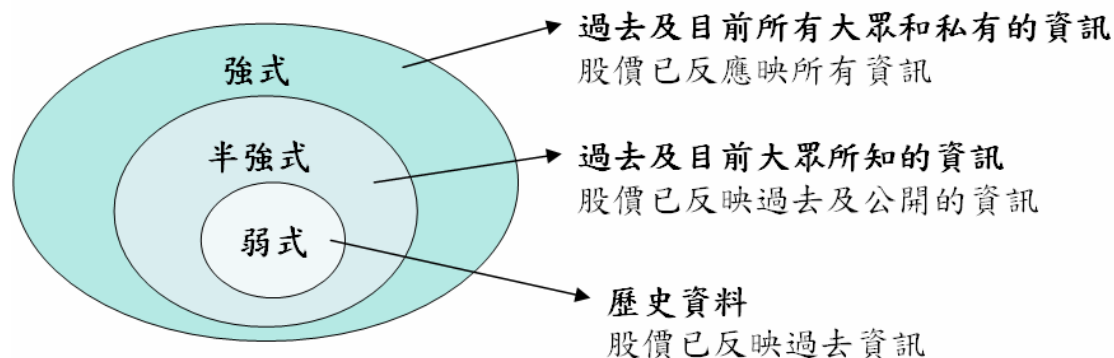
過去的價格變化、交易量及其他的資訊已充候地反應於價格上；因此，使用過去的資料來分析目前的市場狀況，並無法獲取超額利潤。要判斷市場之弱勢效率是否存在，可經由技術分析來驗證。

(2)半強勢效率市場(semi-strong form efficient market)

過去及目前所有大眾皆已知的資訊(包括價格變化、交易量、財務報表及其他資訊息)已充分地反應於價格上；因此，使用大眾皆知的資料來分析目前的市場狀況，並無法獲得超額利潤。要判斷市場是否具有半強勢效率，可經由基本分析來驗證。

(3)強勢效率市場(strong form efficient market)

過去及目前所有大眾或私有的資訊已充分地反應於價格上；因此，無論使用大眾皆已知或私有(未公開)的資訊皆無法預測市場的情況，所以無法獲得超額利潤。因此，強勢效率市場假說所注重的除了公開的資訊之外，再研究那些可以取得內幕消息人士，是否可以獲取超額利潤，即可驗證強勢率市場是否存在。



圖一：不同型態效率市場假說的資訊

資料來源：[6]

上述這三種不同的效率型態之間的差異，在於資訊的內容不同，它們之間的資訊彼此是具有涵蓋性的。如[圖一]表示這三種效率市場假說資訊內容的關係。三種效率市場假說是在程度上有差別，如果強式效率市場假說成立，半強式及弱式效率市場假說也會成立；而當弱式效率市場假說不成，半強式及強式效率市場假說也不成立。

台灣的目前的股市有上下漲跌 $\pm 7\%$ 的限制，資訊並無法完全反應在股市之指數的變化上。因此，利用過往股價及成交量之變化資料可以找出獲取超額報酬的相關資訊。

(二)隨機漫步理論(random walk theory)

1953 年 Kendall 提出股票價格呈現隨機漫步的論點，也就是指股價的變動是獨立地，其間並無一規律性或週期性存在，認為倘若分析過去或現在的股價，對於預測未來之股價是毫無助益。之後，於 1964 年 Osborn 亦發表以物理學的「布朗運動」來說明股價符合隨機漫步的特性，其後 1965 年亦認為證券價格的變動具有隨機性[16]。

二、股票市場分析

股票市場分析一般可以從「基本分析」及「技術分析」兩方面著手。；而技術分析則包括了「圖型分析」及「數量分析」等。

(一)基本分析

基本分析包括了「國際及政治事件」、「總體經濟環境」、「產業情況」及「個別企業」等。以國際及政治事件來說，影響因素包括了戰爭、天災、人禍、國際制裁、國際性會議或談判、大型跨國金融機構倒閉、政府之政策及干預、選舉、立法、全面性罷工等事件等。以總體經濟環境而言，影響因素則包括了所得、利率、匯率、物價、油價、景氣及稅率等。以產業情況而言，影響因素則包括了產對類別、產業之生命週期位置等。以個別企業而言，影響因素則包括了該企業的財務報表及企業的個別事件等[6]。

(二)圖形分析

以過去股價的歷史資料繪製成圖形，以供研判未來的趨勢。如以每日、周、月之開盤價、最高價、最低價及收盤價所繪製之 K 線圖形。利用 K 線有無上、下影線及本身為陰線、陽線或平盤，產生了十二種變化，以了解買、賣雙方的力道，及未來可能的變化。或是以過去股價常出現的形狀來判斷未來的走勢，當過去的圖去即將形成某一種型態時，便可以用預測未來股價的走勢，作為買賣的參考，即是所謂的型態分析(pattern analysis)。如，道氏理論(Dow theory)、艾略特波段理論(Elliott wave theory)或是葛蘭碧(J. Granville)移動平均原則[20]是這方面著名的型態分析。

(三)技術分析[11]

1.移動平均線(moving average，MA)

移動平均線是利用統計學上『移動平均』的原理，將一定期間內的股價相加並加以平均，得出一個平均值，然後將其連接取得之平均線，即為「移動平均線」。

買賣決策：

(1)短期移動平均線由下往上穿越長期移動平均線時即為買進訊號。

(2)短期移動平均線由上往下跌破長期移動平均線時即為賣出訊號。

2.相對強弱指標(relative strength index，RSI)

RSI 主要以股上漲與下跌的趨勢，判斷市場為超買或超賣，以決定應買進或賣出股票[27]。

買賣決策：

(1)RSI < 20，股價跌幅已深，為買進訊號。

(2)RSI > 80，股價漲幅已高，為賣出訊號。

3.隨機指標(stochastics , KD)

隨機指標(KD)綜合動量的觀念、強弱指標(RSI)與移動平均線(MA)的優點發展而成。其中 K 是快速平均線，D 是慢速平均線。

買賣決策：

- (1)當 K 值大於 D 值，顯示目前是向上漲升的趨勢，因此在圖形上 K 線向上突破 D 線時，或 K 值小於 20 位於超賣狀態，即為買進訊號。
- (2)當 D 值大於 K 值，顯示目前是向下跌落，因此在圖形上 K 線向下跌破 D 線，或 K 值大於 80 位於超買狀態，即為賣出訊號。

4.聚散指標(moving average convergence and divergence , MACD)

聚散指標又稱指數平滑異同平均線(MACD)，基本原理是運用兩條速度不同的指數平滑移動平均線來計算兩者之間的差離狀態(DIF)，然後再對 DIF 進行平滑移動平均線即為 MACD 線。簡言之，MACD 就是對長期與短期的移動平均線收斂或發散的徵兆，加以雙重平滑處理，用以研判買賣股票的時機與訊號。

買賣決策：

- (1)DIF 與 MACD 均在水平軸下方，且 DIF 由下往上穿過 MACD 線為買進訊號。
- (2)DIF 與 MACD 均在水平軸上方，且 DIF 由上往下穿過 MACD 線為賣出訊號。

5.乖離率(bias)

乖離率乃是用以目前股價水準與過去平均水準作比較，判斷是否應買進或是賣出股票。當股價偏離平均線時，它最終應該都會回歸平均線的平衡狀態。

6 日買賣決策：

- (1)6 日乖離率達到+3.5%以上、12 日的乖離率達到+5.0%以上是賣出時機。
- (2)6 日乖離率達到-3.5%以下、12 日的乖離率達到-4.5%以下是買進時機。

n-m 日買賣決策：(n<m)

- (1)-m 日 Bias 向下跌破 0 為賣點。
- (2)n-m 日 Bias 往上突破 0 為買點。

6.威廉指標(Williams' Oscillator , W%R)

廉指標(W%R)[23]是運用股市的擺動點來量度其超買超賣現象，可以量度循環期內的高點或低點，提出有效率的投資訊號。

買賣決策：

- (1)W%R 進入 80%至 100%之間進入超賣狀態，80%的線稱為「買進線」。
- (2)W%R 進入 20%至 0%之間進入超買狀態，20%的線被稱為「賣出線」。

7.動量指標(MTM)

即是將股價波動類比於物體運動中的加速、減速到停止；甚至倒退的過程。股價漲幅與跌幅會隨著時間的流逝，而變化逐漸減少，最終必然產生行情反轉。動量指標就是計算證券價格波動的速度，確認其行情到達強勢頂部或進入弱勢底部的時機。


買賣決策：

- a. 一般 MTM 較常與 10 日動量值移動平均線配合使用。當 MTM 位於橫軸上方，由上往下穿過平均線則為賣出訊號。
- b. 當 MTM 位於橫軸下方，且其由下往上穿過平均線則為買進訊號。

三、類神經網路

(一)類神經網路原理

類神經網路系統，是模擬生物神經的運作方式，利用資料不斷的學習及錯誤修正以達到正確的輸出。類神經網路的主要特點是大量的平行處理、非線性輸出及利用多層結構的預測能力。處理單元(processing element, PE)是類神經網路最基本的組成單位，每一個處理單元的輸出必須連結到下一層的處理單元，下一層處理單元的輸入值來自於上一層每個處理單元的輸出值之加總，如[圖二]所示。處理單元的輸出值與輸入值的方程式，一般可以用輸入值與連結加權乘積之和的函數來表示：



圖二：類神經網路處理單元

$$Y_j = f(\text{net}) = f\left(\sum_i W_{ij} X_i - \theta_j\right) \quad (1)$$

其中， Y_j ：類神經網路處理單元的輸出訊號。

X_i ：輸入變數。

net：集成函數。

θ_j ：類神經網路處理單元的門檻值(threshold value)。

W_{ij} ：類神經網路各處理單元間的連結加權值(weights)，介於處理單元間的資料傳遞路徑之間。其符號表示前層第 i 個處理單元對後層第 j 個處理單元之影響強度。

f ：類神經網路處理單元的轉換函數(transfer function)，利用從其它處理單元輸入的輸入值與連結權重值相乘之和，經由處理單元轉換函數得到輸出值。

(二)轉換函數

1.S 型曲線函數(sigmoid function)，輸出值介於 0~1 之間：

$$f(\text{net}) = \frac{1}{1 + \exp^{-\text{net}}} \quad (2)$$

2.雙曲線正切函數(hyperbolic tangent function)，對稱於原點，輸出介於-1~1間之函數

$$f(net) = \frac{1 - \exp^{-net}}{1 + \exp^{-net}} \quad (3)$$


3.Pure Linear 線性轉換函數

$$f(net) = net \quad (4)$$

(三)倒傳遞類神經網路

類神經網路的架構中最被廣為應用的是倒傳遞類神經網路 (back propagation neural network，簡稱 BPNN)，如[圖三]所示。屬於監督式學習網路的一種。

1.倒傳遞網路架構



圖三：倒傳遞類神經網路模型

資料來源：[8]

輸入層：用以表示網路的輸入變數，處理單元之數目依問題而定，使用線性轉換函數。

輸出層：其處理單元的數目依問題而定，若輸出值為單一實數值，則輸出層的處理單元數目設為 1，若是分類問題，則視分類的多寡來決定處理單元數目。

隱藏層：用以表示輸入單元間之交互作用。其處理單元的數目多寡與隱藏層的層數並無特定之方法可循，目前許多研究大多以過去累積之經驗法則來決定隱藏層之層數與處理單元之數目；一般而言，隱藏層處理單元的數目依問題的複雜度而增加，但過多的處理單元會造成網路的記憶現象(memorization)而缺乏歸納能力，但若隱藏層之處理單元數目太少，網路則無法獲得正確之輸入與輸出間的對映關係。

根據 Beal 與 Jackson[13]的說法，類神經網路擁有一層隱藏層可以模擬任何的連續函數。而依據我們想要逼近真實的模式之程度，可以使用十個、百個，甚至上

千個隱藏層的節點數。然而實際上，對於相同的問題，一般人並不會使用有只有一個隱藏層而內含千個以上的處理單元之類神經網路，而是比較希望使用多些隱藏層及較少的神經元的方式來做。

Freisleben[15]認為較好的神經元數目為輸入變數個數(n)乘上 k 倍，再減 1。

$$\text{隱藏層數目} = (k * n) - 1 \quad (5)$$

但是 Refenes[25]認為考量收斂性(convergence)與一般性(generalization)，比較穩定的類神網路架構為“3-32-16-1”。目前，一般較常使用的法則是「輸入變數個數乘上輸出變數個數」，再取「根號值」；而次一層隱藏層的神經元數目為「上一層神經元之數目取對數(ln)值」。

$$\text{隱藏層數目} = \sqrt{\text{input} \times \text{output}} \quad (6)$$

$$\text{隱藏層數目} = \ln(\text{No_of_nodes_in_previous_layer}) \quad (7)$$

然而，到底是那一種方式最佳實際上並無明確的定義，只能說在某些案例下，某些經驗法則可以有比較好的結果。

倒傳遞類神經網路基本原理是利用最陡坡降法(the gradient steepest descent method)的觀念將誤差函數予以最小化。每當輸入一個訓練範例，網路即小幅調整連結加權值的大小，調整的幅度和誤差函數對該加權值的敏感程度成正比，即與誤差函數對加權值的偏微分值大小成正比[8]。

$$\Delta W = -\eta \frac{\partial E}{\partial W} \quad (8)$$

其中， η ：學習速率(learning rate)，控制每次權重值修改的幅度大小。

方程式(9)為誤差函數(或稱能量函數)表示學習的品質。E 愈大表示誤差愈大，網路品質愈不佳；反之，則愈好。

$$E = \frac{1}{2} \sum (T_j - Y_j)^2 \quad (9)$$

其中， T_j ：訓練範例之輸出層第 j 個輸出單元的「目標輸出值」；

Y_j ：訓練範例之輸出層第 j 個輸出單元的「推論輸出值」。

誤差函數對網路隱藏層第 i 個單元與輸出層第 j 個單元間之連結加權值 W_{ij} 的偏微分可用微積分的連鎖律(chain rule)得

$$\frac{\partial E}{\partial W_{ij}} = \frac{\partial E}{\partial Y_j} \frac{\partial Y_j}{\partial \text{net}_j} \frac{\partial \text{net}_j}{\partial W_{ij}} = -(T_j - Y_j) \cdot f'(\text{net}_j) \cdot X_i \quad (10)$$

定義 δ_j 為輸出層第 j 個輸出處理單元的誤差量：

$$\delta_j = (T_j - Y_j) \cdot f'(net_j) \quad (11)$$

則網路輸出層與隱藏層間連結之加權值 W_{ij} 之修正量：

$$\Delta W_{ij} = -\eta \frac{\partial E}{\partial W_{ij}} = \eta \cdot (T_j - Y_j) \cdot f'(net_j) \cdot X_i = \eta \cdot \delta_j \cdot X_i \quad (12)$$

同理，輸出單元的門檻值修正量：

$$\Delta \theta_j = -\eta \frac{\partial E}{\partial \theta_j} = -\eta \cdot \delta_j \quad (13)$$

經由方程式(11) 至 方程式(13) 重複計算，並且一層層向後修正與得出各層類神經處理單元間的權重值及各類神經元的門檻值修正量，逐漸縮小網路輸出值與目標值的誤差，而達到網路模型建立的目的。

通常方程式(12)、方程式(13)在應用時會加上一個慣性因子“ α ” (momentum coefficient, mc)，即加上某個比例的上次加權值的修正量以改善收斂過程中振盪的現象，使訓練過程較為平順。因此，改寫成以下：

$$\Delta W_{ij}(n) = \eta \delta_j X_i + \alpha \Delta W_{ij}(n-1) \quad (14)$$

$$\Delta \theta_j(n) = -\eta \delta_j + \alpha \Delta \theta_j(n-1) \quad (15)$$

類神經網路在訓練時，可以設定訓練的樣本重覆多次的學習循環(learning cycle)，直至誤差收斂為止。但有時為求網路的一般化(generalization)，訓練循環不宜設得太長久，以免訓練的類神經網路產生過度學習(over fitting)的狀況，而使得新輸入的樣本無法正確推導。

四、國、內外相關研究

(一)國內相關研究

An-Sing Chen, Mark T. Leung 及 Daouk[12] 等人，利用貝氏機率類神經網路，結合視窗移動(sliding window)的方法，來預測台灣股市。預測時期分短、中及長期(3、6 及 12 個月)的投資時間。輸入的變數因應不同的投資時間長短，而有所不同。結果發現機率類神經網路的預測輸出值，結合在上漲機率大於 0.7 之後買入股票，上漲機率小於 0.5 時賣出股票，而上漲機率位在 0.5 與 0.7 之間時則持平的「多個門檻(multiple threshold triggering)」的交易策略，相較於「buy and hold」、「random work」、「GMM-Kalman Filter」及上漲機率大於 0.5 之後買入股票，上漲機率小

於 0.5 時賣出股票，上漲機率等於 0.5 時持平時的「單一門檻(single threshold triggering)」交易策略，有較佳的報酬率。

薛淑如[10]，以基本面的資料做為預測個股漲跌的研究，模式摒棄了傳統類神經網路配合時間序列的討論，認為傳統類神經網路在時間資料的處理上都不盡完善。對象為國內數家上市公司以及美國道瓊股市成份股之基本財務資料來當作訓練樣本，國內是以財報公佈前一日，美股則是以固定期間為基準，以未來兩週內股價相對於指數的漲跌程度當作輸出。針對所提供的訓練樣本類神經網路可以快速的收斂完成訓練，並應用在訓練樣本以外其他類似股票的投資決策輔助。結果顯示，正確率能達到 60%以上。

吳宗正、溫敏杰、候惠月等人[5]，利用類神經網路、迴歸模式、時間數列和改良後類神經網路，以台灣證券股價指數期貨近月份合約的資料為研究對象，以 14 個變數(包括當日開盤價、收盤價、最高價、最低價、成交口數、漲跌、前日未平倉量、時距、基差、移動平均線、6 日 RSI、9 日 KD 值、差離柱線)作為模式之輸入變數，來預測台股指數期貨的隔日收盤指數。並比較各模式的預測效果。結果發現預測績效模式優劣順序分別是：改良後類神經網路、迴歸模式、類神經網路模式、時間數列模式。

(二)國外相關研究

Jingtao Yao、Chew Lim 和 Hean-Lee Poh [20] 採用多項技術指標以倒傳遞類神經網路來預測新興股票市場—吉隆坡證券交易所股票市場未來一日的收盤價。採用的技術指標包括了過往一日的收盤價、MA、動量(momentum)，RSI、KD 等指標。並與時間數列 ARIMA 比較預測準度。結果發現應用三層(6-4-3-1)的類神經網路較其它網路模式擁有較佳的預測結果與報酬率。

Qing Cao, Karyl B. Leggio 及 Marc J. Xchniederjans 等人[13]，以類神經網路預測中國上海證券交易所的股市。類神經網路模式打敗多種線性的預測模式。在統計上是顯著性地具有差異，足見類神經網路可以有效預測像中國這般正在開發，股票市場處在正在成長的階段的國家。

Gencay Ramazan[17]，運用平均移動法則當作類神經網路判斷股票買進賣出的指標，並在長期移動平均線與短期移動平均線接近時，設一區間，避免因股價波動造成買進賣出訊號誤判。以 AR，GARCH-M 兩種線性模式和倒傳遞類神經網路非線性模式進行預測，結果發現非線性倒傳遞類神經網路模式預測能力較好。

Kai Fu and Wenhua Xu[22]，利用遺傳演算法類神經網路以上海之股票指數為預測目標，結果顯示遺傳演算法配合類神經網路對於短期股價預測有很好的預測效果。

White **錯誤! 找不到參照來源。**提出利用 Harrison-Kreps-Pliska 三人所提出的網路模型來學習 Black-Scholes 評價模式，以 CBOE、OEX 及 S&P500 的買權價格資料，作為訓練及檢定類神經類神經網路績效之用。實證結果顯示，類神經網路用於選擇權訂價上為一有用的工具。

Hauser and Lauterbach[19] 提出正確的評價模型為可獲得較高超額報酬的模

型。實證結果顯示，考慮稀釋效果下，SRCEV 模型較 Black-Scholes 評價模式可獲得更高的超額報酬。

Hank[18] 提出以德國 DAX 歐式買權所進行的網路訓練與績效評價。實證結果顯示，類神經網路的評價誤差顯著小於 Black-Scholes 模型的評價誤差，即類神經網路的評價準確性高於 Black-Scholes 模型。

參、本研究之預測模型與交易策略

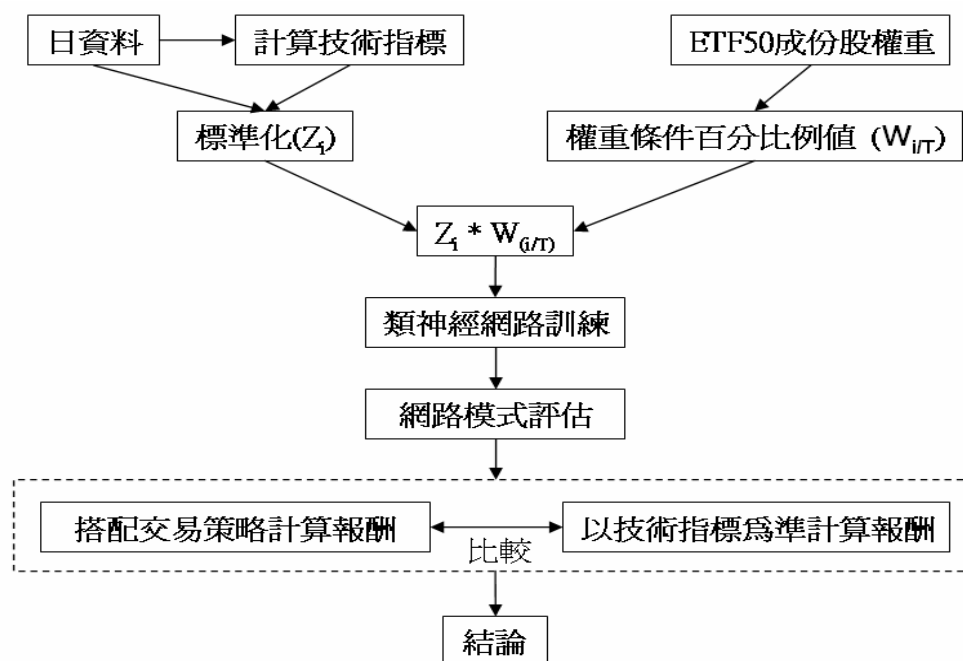
日資料的來源為台灣證券交易所[1]，以在該網站所能收集到之 ETF50 日資料最大範圍為主，收集時間範圍為 2003 年 6 月 30 日至 2005 年 6 月 16 日，有 491 筆日資料，扣除開始之初因計算指標而消耗的 35 筆資料，餘計有 456 筆資料。其它 ETF50 排名前 20 名之各股日資料的收集範圍則與收集到 ETF50 的日資料範圍相同。將日資料切割為兩段，前段 356 筆資料做為訓練建立類神經網路模型之用，後段 100 筆做為測試類神經網路模型預測結果之用。其切割情形如[圖四]所示：



圖四：資料樣本切割情況

一、研究架構

本研究的方法，是收集各股之日資料後，計算個股的技術指標，將資料予以標準化後，再與其相對應的權重條件百分比相乘，然後配合類神經網路訓練以塑造預測模型。訓練完成之類神經網路經評估後，選擇出較佳的模型與交易策略配合，模擬得出投資報酬率，再與各項指標所得出之投資報酬比較。研究架構如[圖五]所示。



圖五：研究架構圖

之所以採用這樣的方式，主要原因是 ETF50 股價指數的組成，是選取台灣 50 個上市企業股票市值最大的股價依市值比例加總而成，即「一籃子股票」的概念。因此，類神經網路之輸入變數，會考慮各股票在 ETF50 成份股本身所佔的的市值百分比比例，而將輸入變數標準化後乘上該股票所佔有的「權重值」。考量 ETF50 的成份股並非固定企業之股票，而是隨市值的大小而變動，所以為使類神經模型較穩定，對於那小市值排名小且變動性較大的企業並沒有納入本研究的樣本，所以最後只檢選前 20 家市值最大之股票為本研究對象。考量本實驗只選取 ETF50 成份股排名前 20 名之各股及 ETF50 股價指數本身之資料。因此，將各股的「權重值」重新計算化為「權重條件百分比值(W_{iT})」，以反應各股的日資料變數在本研究中類神經網路所佔之實際影響比例。

文獻中類似的研究，其研究的對象是一般上市企業的股票為主，與 ETF50 以一籃子股票概念組成的方式不同。因此，一般的研究是以單一企業股票過往之資料來預測未來之股價；而本研究是以過往 ETF50 成份股排名前 20 名及 ETF50 本身共 21 支股票的資料，來預測未來 ETF50 這支股價指數。此處是本研究架構與其它研究不同之處。另外，本研究所提出之交易策也是與其它研究不同之處。

二、類神經網路模型

本研究的類神經網路採用倒傳遞網路模式，穩藏層所使用的轉換函數為雙曲線正切函數(hyperbolic tangent function)，輸出層所使用的轉換函數為 Pure linear 線性轉換函數。

(一)類神經網路架構

隱藏層層數有 0、1、2 層，至於隱藏層的類神經元數目，則採用方程式(6)及方程式(7)之計算方式。每一個類股計有 18 個輸入變數，共有 21 支股票，因此計有 378 個輸入變數。

$$\text{Input} \rightarrow 21 * 18 = 378$$

$$\text{Output} \rightarrow 1$$

第一層穩藏層神經元數目(參考方程式(6))：

$$\sqrt{\text{input} \times \text{output}} = \sqrt{378} = 19.44$$

第二層隱藏層神經元數目(參考方程式(7))：

$$\ln(19.44) = 2.94$$

因此，在二層隱藏層之類神經元的數目設計上，吾將第一層隱藏層之神經元數目加上 2 及 4，所以計有 19、21 及 23 等三種；在第二層隱藏層之神經元數目則加上 2 及 4，所以計有 3、5 及 7 等三種。另外，在一層隱藏層之類神經元的數目設計上，吾將隱藏層之神經元數增加(高於 19)，計有 25、28、30、35、及 40 等五種。主要考量是若隱藏層數目較少，則類神經元之數目宜多一些，以幫助建構

適應複雜問題的模型。茲將實驗之類神經網路模式，整理如[表一]所示：

表一：類神經網路模式

0 層隱藏層	1 層隱藏層	2 層隱藏層
378 → 1	378 → 25 → 1	378 → 19 → 3 → 1
	378 → 28 → 1	378 → 19 → 5 → 1
	378 → 30 → 1	378 → 19 → 7 → 1
	378 → 35 → 1	378 → 21 → 3 → 1
	378 → 40 → 1	378 → 21 → 5 → 1
		378 → 21 → 7 → 1
		378 → 23 → 3 → 1
		378 → 23 → 5 → 1
		378 → 23 → 7 → 1

(二)類神經網路參數設定

「學習速率」太大或太小對網路的收性質均不利，依據經驗取 0.1 到 1.0 間的學習速率值，大都可得到良好的收斂性 [8]。本研究在學習率(η)採用了 “ 0.2、0.3、0.5、0.7 及 0.8 ” 等四個值。

通常「慣性因子」太大或太小對網路的收斂性均不利。在學習過程中，慣性因子可採先取較大的初始值，再於網路的訓練過程中逐漸減小的方式來設定[8]。本研究在慣性因子上設定了 0.5、0.7、0.8 及 0.9 這四個值。

學習過程通常以一次一個訓練範例的方式進行(稱之為「逐例學習」)，直到學習完所有的訓練範例，稱為一個學習循環(learning cycle)。一個網路可以將訓練範例反覆學習數個學習循環，直至達到收斂為止。如果學習過程改以一次多個範例的方式進行，即累積多個訓練範例後再修改權值一次的方式進行，稱之為「批次學習」(batch learning)。本研究在每個類神經網路中均設定逐例學習及批認學習的參數，實驗中會先進行逐例學習 3000 次後，再進行 5000 次批次學習。

(三)輸入變數

本研究採用之類神經網路輸入資料，為一般大眾常用之技術指標，另外再加入過往五日之收盤價及次日的成交量資料。本研究之所以採用這些技術指標為輸入變數，主要考量為取得方便，使用上也容易。

至於國內 ETF50 股價指數與國外之國外股價指數之連動性並未考慮進去。世界各國股市價格之間領先及落後(Lead and Lag)的相互關係的確存在[8]，而國內外股價指數之間的連動性也的確存在著關連性[3][4][7]。因此在未來或許可將之納入本實驗之後續之研究中！

台灣 ETF50 股價指數是採用「一籃子股票」的概念而形成的，因此即利用此一概念選擇排名前 20 名(占 ETF50 的 74%)及 ETF50 本身的股票指數的其相關技術指標，做為系統的投入變數。另外，各技術指票大部份是由股價最高、最低、開盤及收盤價配合時間所計算而得。所以變數的選用上會有許多的重疊性。但是利用倒傳遞類神經網路具有對權重值自我微調之特性，可以將具有影響的差異性突顯出來，並降低重疊性的影響。對於重疊性的影響可以利用統計之方法，如 ARIMA 將主要關鍵變數找出。未來此部份也是本研究需進一步探究的地方。

$$\hat{P}_{t+1} = f(X_1, \dots, X_k, \dots, X_K) \quad (16)$$

其中， \hat{P}_{t+1} ：第 t+1 日的收盤價之預測值；
 X_k ：輸入的變數。(k = 1, 2, ..., 24)，
 各變數說明，如[表二]所示：

表二：輸入變數說明

變 數 (X _k)		說明
X ₁ ~ X ₅	P _t P _{t-1} P _{t-2} P _{t-3} P _{t-4}	過往 5 日的收盤價
X ₆	Deal	當日成交量
X ₇ X ₈	%K %D	9 日隨機指標
X ₉ X ₁₀	MA6 MA12	6 日及 12 日移動平均線
X ₁₁ X ₁₂	Bias 3-6Bias	6 日及 3-6 日乖離率
X ₁₃	RSI6	6 日強弱指標
X ₁₄	W%R12	12 日威廉指標
X ₁₅ X ₁₆	MTM6 MTM(avg6)	6 日動量指標及均線
X ₁₇ X ₁₈	MACD DIF	10 日聚散指標及 10 日差離值

1.標準化 (Z_i)

為避免變數的數值範圍差異過大，造成訓練類神經網路之時，產生較大的誤差。因此，變數均先行處理進行“標準化”，使輸入之變數數值對應在「-1 ~ 1」之間[8]。

$$Z_{ti} = \frac{X_{ti} - \mu_i}{k \cdot \sigma_i} \quad (17)$$

其中， Z_{ti} ：變數 i 在第 t 日標準化後之變數值；
 X_{ti} ：變數 i 在第 t 日之原始數值；
 μ_i ：變數 i 之平均數；
 σ_i ：變數 i 之標準差；
 k ：對映比例之參數，設定為 1.96。有“95%”之原始數值對映到「-1 ~ 1」之間。

2.條件百分比率 (W_{i/T})

ETF50 成份股權重值的部份，以成份股之實際之權重值為準；而 ETF50 本身的權重值部份，則設定為 100%。先將 20 支 ETF50 成份股及 ETF50 本身之權重值日加總計算總權重(W_T)，再計算各股之條件百分率值(W_{i/T})。以 2005/1/3 日之股價為例，經計算以得到各個股票在該日之權重條件百分比比例值，如[表三]所示

$$W_T = \sum W_i \quad (18)$$

$$W_{(i/T)} = \frac{W_i}{W_T} \times 100\% \quad (19)$$

其中， W_i ：股票之權重比例

W_T ：總權重

$W_{i/T}$ ：條件百分比率

表三：ETF50 輸入類神經網路之各股資料條件百分比率值

排名	編號	名稱	ETF50 成份股 權重(W_i)	條件百分比率 ($W_{i/T}$)
—	0050	台灣 50	100%	57.45%
1	2330	臺積電	14.88%	8.55%
2	2317	鴻海	5.51%	3.17%
3	1301	臺灣塑膠	4.39%	2.52%
4	2303	聯電	4.00%	2.30%
5	2002	中國鋼鐵	3.84%	2.21%
6	1303	南亞塑膠	3.82%	2.19%
7	2882	國泰金	3.75%	2.15%
8	1326	臺灣化纖	3.73%	2.14%
9	2412	中華電信	3.24%	1.86%
10	2891	中信金	3.21%	1.84%
11	2409	友達	3.09%	1.78%
12	2881	富邦金	2.89%	1.66%
13	2886	兆豐金	2.72%	1.56%
14	2357	華碩	2.56%	1.47%
15	2454	聯發科	2.37%	1.36%
16	3009	奇美電	2.34%	1.34%
17	2883	開發金	2.20%	1.26%
18	2887	台新金	1.96%	1.13%
19	2353	宏碁	1.91%	1.10%
20	2892	第一金	1.64%	0.94%
			W_T : 174.05 %	$\sum(W_{i/T}) = 100\%$

3.計算 $Z_i * W_i$

以計算台積電 2005 年 1 月 3 日之輸入變數($Z_i * W_i$)為例：

首先計算 391 筆台積電樣本的收盤價之平均值(μ_i)及標準差(σ_i)。其次將之標準化計算 Z 值。

$$\mu = 55.27851$$

$$\sigma = 8.524412$$

$$Z = \frac{50.4 - 55.27851}{1.96 \times 8.524412} = -0.29199$$

計算台積電的條件百分比率：

$$W_{(\text{台積電}/T)} = \frac{0.1488}{1.7405} \times 100\% = 8.55\%$$

計算輸入變數($Z_i * W_i$)

$$Z_i * W_i = -0.29199 \times 8.55\% = -2.4965\%$$

(四)輸出變數

類神經網路輸出之變數為 ETF50 隔日之收盤股價指數。

三、交易策略 -- 連續兩次轉換

蔡依玲[9]以「台灣電子類股之週加權股價指數」為研究對象，交易策略是採取一買一賣或一賣一買的交易方式，即在研究期間內，若是多頭市場則第一次出現買進的訊號即買進，直到出現第一次賣出的訊號才予以賣出，期間如有買進的訊息則不操作。但若是空頭市場時則採第一次出現賣出的訊號時則放空，直到出現第一次買進的訊號才予以買進，期間如有賣出的訊號亦不操作。

由於上述研究需以人工的方式判斷是位在多頭或是位在空頭，再以類神經網路模擬輸出之買、賣時點決定買或賣。為了減少買、賣訊號過於敏感，以及避免人工的方式介入判斷多、空趨勢，並且有效降低交易成本，本研究提出了「連續兩次的轉換」類神經網路輸出訊號的交易策略。

(一)一次轉換

一次轉換結果主要是以「一日預測之報酬率」來判斷買、賣的時點。其計算方式如方程式(20)所示。當一日的報酬率超過上限門檻值則買；當一日的報酬率低於下限門檻值則賣；若是介於上下限門檻值之間則持平。

$$f(\text{rate}) = \frac{\hat{P}_{t+1} - P_t}{P_t} \quad (20)$$

其中， $\hat{f}(\text{rate})$ ：預測之報酬率

\hat{P}_{t+1} ：預測明日之收盤股價指數；

P_t ：今日實際之收盤股價指數。

上、下限門檻值的決定，主要考量的是買賣 ETF50 時所花費之交易成本為主，買入時所花之成本為股票本金之 1.425%(手續費)；賣出時所花之成本為股票本金之 2.425%(1.425% 的手續費及 1% 的證交稅)。所以將「預測之報酬率」之上限門檻值設定於 1.425%，下限值則設定為 -2.425%，一次轉換交易策的方式條列如下：

若 $\hat{f}(rate) > 1.425\%$ 則為 “買訊” ；

若 $-2.425\% \leq \hat{f}(rate) \leq 1.425\%$ 則為 “持平” ；

若 $\hat{f}(rate) < -2.425\%$ 則為 “賣訊” 。

(二) 連續兩次轉換

實際上，經由「一次轉換」的結果，其買、賣訊號過於敏感，且過於頻繁的交易會使得交易成本快速地增加。而且，股市中的線型中經常出現連續漲或連跌的情現。因此，本研究提出「二次轉換」的交易策略，以有效降低交易之次數及交易成本。此交易策略介紹如下：

1. 若『連續出現兩次買訊』，則『買入』(若之前為放空則先回補再買入)；
2. 若『連續出現兩次賣訊』，則『放空』(若之前買入則先賣出再放空)；
3. 其餘情況則延續前次已買或已賣之動作而維持『持平』，並不加買或加賣之動作，直到出現上述(1)或(2)任一種情況，才轉換為買或賣。
4. 在最後一日之交易時，不管是原來是買或賣，均需出場結算報酬率。

經由連續二次轉換步驟後所得之買、賣時點，為本研究交易策模擬時所採用之真正買、賣時點。以 10 日的模擬交易情況為例加以說明，如[表四]所示：

表四：交易策略 -- 連續兩次轉換

時間	1	2	3	4	5	6	7	8	9	10
一次轉換	賣	賣	買	買	持平	賣	賣	買	賣	持平
二次轉換 (交易策略)	——	放空	持平	回補 並 買入	持平	持平	賣出 並 放空	持平	持平	回補 並 結算

四、評估方式

此部份區為兩部份：一是訓練後類神經網路的評估；二是類神經網路搭配投資策略產生報酬之評估。

(一)類神經網路之評估

一般評估類神經網路在函數性的目題，通常採用「平均絕對誤差(mean absolute error, MAE)」、「平均誤差平方(mean square error)」或「平均誤差平方根(root mean square error, RMSE)」。在本研究中則採用平均誤差平方(MSE)[8]。

平均誤差平方為預測誤差平方和之平均，此方法給予預測誤差較大的權數較重，是最普遍使用的誤差衡量統計量。其方程式表示如下：

$$MSE = \frac{\sum_{i=1}^n (O_i - E_i)^2}{n} \quad (21)$$

其中， O_i 為觀測值；
 E_i 為期望值；
 n 為樣本數。

(二)投資報酬評估

在評估得到較佳的類神經網路模式後，利用 100 筆測試段之日資料模擬產生預測之 ETF50 股價指數，搭配本研究提出之交易策略，以“複利”之計算方式來計算投資報酬率。所得到之報酬率再與以其它常使用之技術指標為買賣決策所獲得之投資報酬率進行比較。

肆、研究發現

本章主要將實驗結果加以分析，首先針對類神經網路模式加評估，找出較佳的網路模式。同時配合連續二次轉換的交易策略，找出較佳的買、賣時點，以所得出之報酬率來評估類神經網路及技術指標之投資報酬高低。由於投入類神經網路之變數高達 378 個，因此，在訓練時所花費的時間成本的確很高，不過相較於可以獲得的投資報酬，仍是非常值得的！

一、類神經網路模式具有良好的預測能力

本研究在網路評估部份是以實際股價與模擬股價平均誤差平方(mean square error, MSE)為主要的評估模式，MSE 愈小則表示實際股價指數，與模擬所得之股價指數誤差愈小，模擬出來的類神經網路的配適度愈佳。

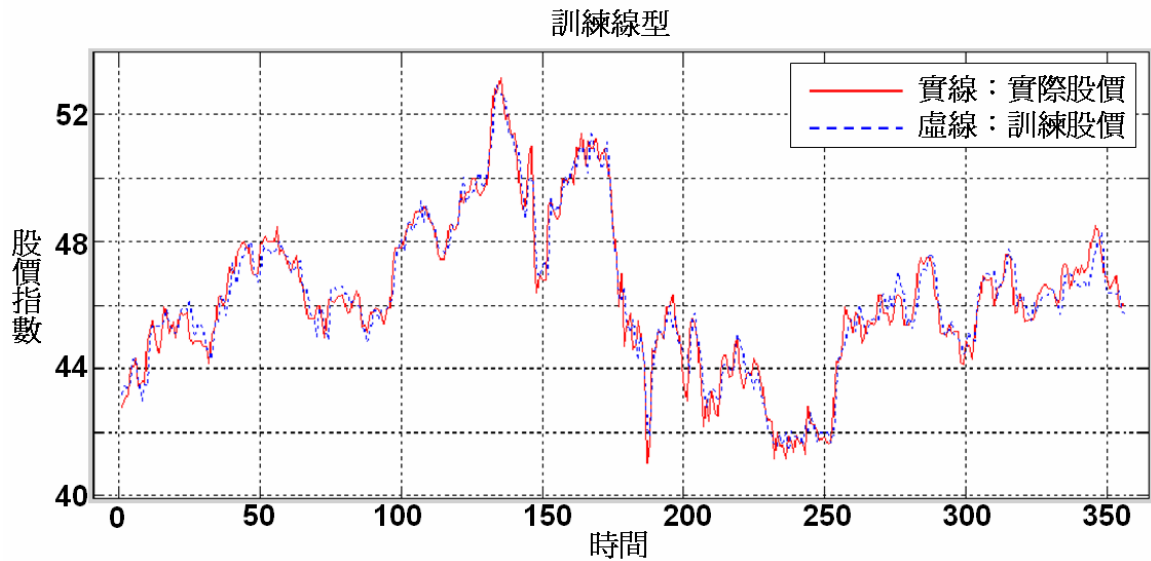
表五：類神經網路“訓練”期之結果

項次	隱藏層數	網路架構	學習率	慣性因子	實際股價	
					訓練期之 MSE	測試期之 MSE
1	2	378-21-5-1	0.5	0.9	0.25798	0.69337
2	2	378-21-3-1	0.5	0.9	0.26581	0.54208
3	2	378-19-3-1	0.7	0.9	0.27094	0.33843
4	2	378-19-3-1	0.3	0.7	0.27186	0.36238
5	1	378-30-1	0.7	0.9	0.32964	0.35879

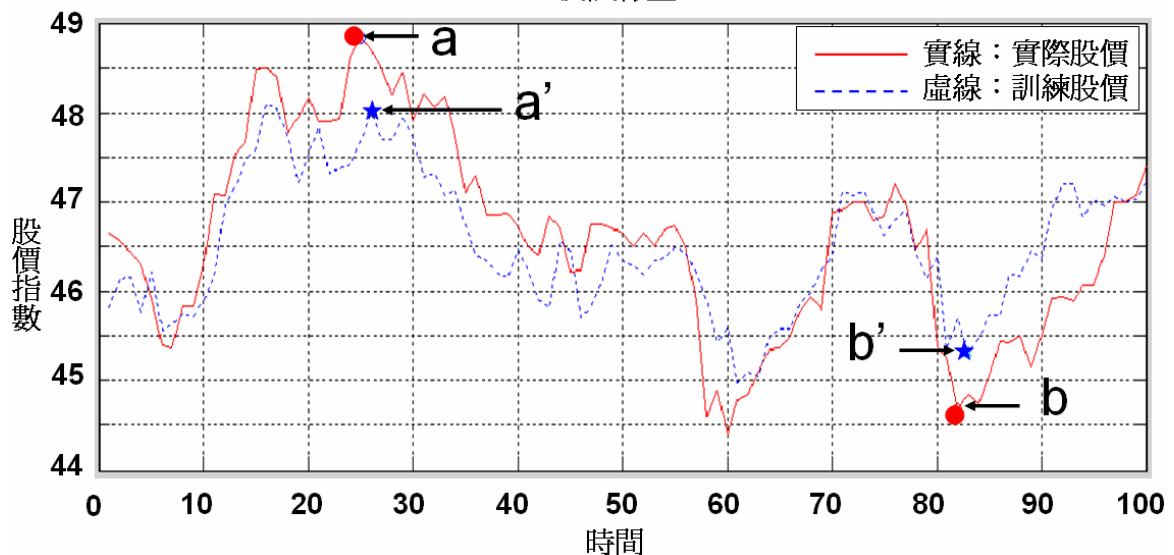
依據類神經網路訓練之結果，選擇出網路訓練期間 MSE 誤差值最小的 5 個網路架構，此 5 個網路架構，應該是較佳的模型。結果如[表五]所示(以訓練期之 MSE 之大小為準，由小到大排序)。

以下兩圖為第 4 個類神經網路模式(378-19-3-1)在訓練期及測試期的實驗線型。[圖六]為「訓練期」的線型(實線為實際股價，虛線為模擬之股價)，可見此類神經網路之模式在訓練期的配適情形良好。

[圖七]為第 4 個網路架構(378-19-3-1)之「測試期」線型(實線為實際股價，虛線為模擬之股價)。若是實際值與模擬值兩者貼近，則此類神經網路模型對 ETF50 具有良好之解釋力。



圖六：訓練期線型
測試線型



圖七：測試期線型

由測試期的股價線型的中期段可以看出，實際的股價指數為下跌之趨勢，而模擬訓練出來之預測股價指數領先下跌，如“a 點”為第 25 日之實際股價，“a’ 點”為第 26 日之預測股價指數，則“ $a > a'$ ”表示在下跌段之預測股價已經漲不上去而開始下跌了；而在後期實際股價指數開始上漲時，預測之股價指數領先上漲，如“b 點”為第 82 日之實際股價指數，“b’ 點”為第 83 日之預測股價指數，“ $b < b'$ ”表示在上漲段之預測股價已經跌不下去而開始上漲了。而在測試期其它的區域，實際股價指數與預測股價指數之線型相近。因此，本研究之類神經網路模式具有良好預測之能力。

二、交易模擬策略

利用本研究提出之交易策略結合類神經網路，利用測試期 100 筆的日資料，計算出投資報酬。如[表六]即是在一次及二次轉換後之買、賣訊號次數統計及複利方式計算投資報酬之結果。

表六：投資報酬

項次	一次轉換					二次轉換(交易策略)				
	買訊 次數	賣訊 次數	持平 次數	報酬(%)		買訊 次數	賣訊 次數	持平 次數	報酬	
				不含 交易 成本	包含 交易 成本				不含 交易 成本	包含 交易 成本
1	45	46	8	30.68	-4.348	3	3	93	25.20	22.89
2	63	29	7	13.35	-22.05	3	3	93	23.60	21.29
3	60	30	9	9.87	-24.77	4	3	91	19.68	16.99
4	35	54	10	23.78	-10.44	4	4	91	27.94	24.86
5	33	65	1	14.70	-23.02	5	6	88	22.90	18.67

結果看出項次 1 的類神經網路架構，以一次轉換之結果為例在不考慮交易成本的前提下，複利報酬可達 30.687%；在考慮交易成本的條件下，計有買入 45 次，賣出 46 次，8 次則不予進場交易。扣除 91 次交易成本則獲利為“-4.348%”，報酬率「由正變負」，可見過於頻繁的交易次數，報酬均被交易成本所侵蝕。

而在二次轉換的交易策略中，將買、賣時點規定為連續兩次的買訊出現，或連續兩次的賣訊出現，才進行買或賣的動作，以降低敏感度。經由這樣的買、賣訊號轉換後，交易次數大幅減少。由上[表六]在二次轉換的部份，可以看出投資報酬率最高的是第 4 個類神經網路架構，在包含交易成本之下，100 日的投資報酬約 25%。一年交易日約 224 日，以複利方式計算不包含交易成本的情況下投資報酬高達約 64%。

$$224/100 = 2.24$$

$$((1 + 0.2486)^{2.24} - 1) \times 100\% = 64.43\%$$

在[表五]中「訓練期」之 MSE 小於「測試期」之 MSE 值，是屬於正常現象。在第一個「378-21-5-1」的網路模式其「訓練期」之 MSE 雖然是最小，但是其「測試期」之誤差卻是 5 個網路模式中 MSE 排名第 2 大的。雖是如此，可由[表六]發現其模式之報酬仍為 5 個網路模式中的第 2 名。可見『預測』這類問題，注重趨勢的變化會比誤差來的得重要。預測趨勢若正確，雖然預測之股價數值與實際股價數值有較大的差距，但是仍能從市場中獲取報酬。

三、以技術指為準之報酬率

以本研究提及之技術指標為買、賣股票之行事標準，用以計算報酬率。當技術指標出現買訊時則買進；出現賣訊則賣出。若是出兩次買點間沒有賣點，則在碰到第二次買點時，並不會再買入或有贖回之動作；反之，兩次賣點間若無買點，則在碰到第二次賣點時，並不會再賣出或再放空。經過計算結果如[表七]所示。

由[表七]所得之結果顯示，最能預測 ETF50 在這 100 日的收盤價的技術指標獲取最高額之報酬為“6 日動量指標及均線”。在包含交易成本之情況下，可獲得之報酬為 17.03%。年投資報酬約為 42%。

$$((1 + 0.1703)^{2.24} - 1) \times 100\% = 42.23\%$$

經由投資報酬率之比較，可以看出本實驗的類神經網路架構配合模擬交易的策略具有較高的報酬率。

表七：以技術指標判別買、賣訊號及計算報酬

技術指標	買訊 次數	賣訊 次數	持平 次數	報 酬	
				不含交易成本	包含交易成本
9 日隨機指標	4	3	92	-0.1395 %	-2.835 %
6 日及 12 日移動平均線	4	3	92	7.213 %	4.518 %
3-6 日乖離率	9	8	82	13.286 %	6.741 %
6 日強弱指標	3	2	94	7.604 %	5.679 %
12 日威廉指標	3	2	94	4.601 %	2.69 %
6 日動量指標及均線	6	6	87	21.665 %	17.03 %
10 日聚散指標及 10 日差離值	4	3	92	3.946 %	1.251 %

伍、結論

ETF50 是由台灣前 50 大之企業所組成之成份股，因此在實驗之初，便考量是否除了 ETF50 本身之相關技術資料之外，可以再加入其它成份股的部分，來做為預測股價指數變化之用？於是抽取了 ETF50 排名前 20 之成份股(佔 ETF50 約 74%之權重)，再加上 ETF50 本身的技術指標，總共 21 個股票之相關技術指標進行實驗。

21 個股票的相關技術指標，形成了 378 個輸入變數，將之標準化避免以及加入權重值之影響，經由類神經網路之訓練，找出誤差率 MSE 最小之五個類神經網路模型進行測試。發現「訓練期」MSE 最小為項次 1 之類神經網路模式「378-21-5-1」；在「測試期」MSE 最小為項次 32 之類神經網路模式「378-19-3-1」。從[圖七]中可看出本類神經網路模式，是具有良好的預測能力的。

將類神經網路的輸出預測次日收盤股價指數經由一次轉換形成買賣之時點，依此結果進行投資，在不考慮交易成本之前提下，最高報酬達到 30%；若在考慮交易成本之下，因為交易次數過多，使投資報酬率由正轉負，報酬均被交易成本所侵蝕！因此，本研究之交易策略係以連續兩次出現買訊或賣訊，做為實驗中真正之買、賣時點，經由 100 日樣本資料驗證所獲得之投資報酬約 25%，相較於只單純以技術指標來判斷買、賣點的方式，可獲取較高的之利潤。

參考文獻

一、中文部份

- [1] 台灣證券交易所，<http://www.tse.com.tw/ch/>。
- [2] 台灣證券交易所與富時指數有限公司合之台灣指數系列，
<http://www.tse.com.tw/ch/products/securities/ETF/variety.php>。
- [3] 李昱翰(2003)，台灣與亞太股市動態相關係數與風險值之研究，國立台北大學企業管理研究所未出版之碩士論文
- [4] 余尚武，游梓堯(2003)，美國與台灣股票市場之連動性與關聯性-VAR、GARCH 與灰關聯分析之應用，經濟情勢暨評論，8(4)，160-186。
- [5] 吳宗正、溫敏杰、侯惠月(2001)，類神經網路及統計方法在台股指數期貨預測研

究之比較，成功大學學報，第 36 卷，人文社會篇，頁 91-109。

- [6] 徐俊明，2004，投資學理論與實務，台北：新陸書局。
- [7] 黃博怡，陳君達(2002)，台灣與美日兩國股市股價的關聯性-分類股價指數門檻 GARCH 模型分析，台灣銀行季刊，53(4)，67-88。
- [8] 葉怡成，1994，應用類神經網路，台北：儒林。
- [9] 蔡依玲，2000，台灣股票市場報酬率之研究，國立成功大學統計學系碩士論文。
- [10] 薛淑如(2003)，應用類神經網路於股票價值之評估，國立彰化師範大學會計學系碩士論文。

二、英文部份

- [11] Andrew W. Lo, Harry Mamaysky, and Jiang Wang, "Foundations of technical analysis: Computation algorithms, statistical inference, and empirical implementation", *Journal of Finance*, 2000, Vol. 55, 1705-1770
- [12] An-sing Chen and Hazem Daouk , Application of Neural Networks to an Emerging Financial Market: Forecasting and Trading the Taiwan Stock Index, *Computers and Operations Research* (2003), Vol. 30, Issue 6, p. 901-923.
- [13] Beal R. and Jackson T., *Neural Computing: An Introduction*, Adam Hilger., 1990.
- [14] Eugene F. Fama, "Efficient capital markets: A review of theory and theory and empirical work", *Journal of Finance*, 1970, V.25, p. 383~417.
- [15] Freisleben B., *Stock market prediction with backpropagation networks*, Industrial and Engineering Application of Artificial Intelligence and Expert System. 5th International Conference, Paderborn, Germany (June 1992) 451-460.
- [16] Fama , Eugene F., "Random Walks in Stock Market Prices", *Financial Analysis Journal* , Sep.-Oct.1965.
- [17] Gencay Ramazan(1996), Non-linear prediction of security returns with moving average rules, *Joural of Forecasting*, Vol.15, p 165-174.
- [18] Hank M. (1999), Neural networks vs. Black Scholes: An Empirical comparison of the Pricing Accuracy of Two Fundamentally Different Option Pricing Methods, *Journal of Computational Intelligence in Finance*, January-February, 1999, p. 26-34.
- [19] Hauser, S., and Lauterbach, B., (1997), The Relative Performance of Five Alternative Warrant Pricing Models, *Financial Analyst Journal*, January, 1997, p. 55-61.
- [20] Jingtao Yao, Chew Lim Tan and Hean-Lee Poh(1999), Neural Networks for technical Analysis: A Study on KLCI.
- [21] Joseph Granville, *Granville's new key to stock Markey profits*, Prentice Hall, Englewood Cliffs, NJ., 1963.
- [22] Kai Fu, Wenhua Xu(1997), Training neural network with genetic algorithms of forecasting the stock price index, *IEEE IOternational Conference Intelligent Processing Systems*, P401-403

- [23] Larry Williams, , How I made one million dollars in the commodity market last year, Conceptual Management, Monterey, CA., 1973
- [24] Qing Cao. Leggio, Karyl B. Schniederjans, Marc J. , (2005), A comparison between Fama and French's model and artificial neural networks in predicting the Chinese stock market, *Computers and Operations Research* Volume: 32, Issue: 10, October, 2005, pp. 2499-2512
- [25] Refenes A. N., Zapranis A. and Francis G., “Stock performance modeling using neural networks: a comparative study with regression models”, *Neural Network*, 1994, Vol. 5, p.961-970.
- [26] White, H. (1996b), Option Pricing in Modern Finance Theory and the Relevance of Artificial Neural Networks, Paper presented at ICONIP' 96, Hong Kong
- [27] Wlles Wilder J., Jr., New concepts in technical trading systems, Tend Research , Greensboro, NC., 1978